

## ⑫ 公開特許公報(A)

平2-96707

⑬ Int. Cl.<sup>5</sup>

識別記号

庁内整理番号

⑭ 公開 平成2年(1990)4月9日

G 02 B 7/28

7448-2H

G 02 B

7/11

N

7448-2H

G 03 B

3/00

A※

審査請求 未請求 請求項の数 1 (全11頁)

⑮ 発明の名称 焦点検出装置

⑯ 特 願 昭63-250466

⑰ 出 願 昭63(1988)10月4日

⑱ 発 明 者 山 崎 正 文 東京都渋谷区幡ヶ谷2丁目43番2号 オリンパス光学工業株式会社内

⑲ 発 明 者 豊 福 敏 之 東京都渋谷区幡ヶ谷2丁目43番2号 オリンパス光学工業株式会社内

⑳ 発 明 者 伊 藤 順 一 東京都渋谷区幡ヶ谷2丁目43番2号 オリンパス光学工業株式会社内

㉑ 出 願 人 オリンパス光学工業株式会社 東京都渋谷区幡ヶ谷2丁目43番2号

㉒ 代 理 人 弁理士 坪 井 淳 外2名

最終頁に続く

## 明 細 書

## 1. 発明の名称

焦点検出装置

## 2. 特許請求の範囲

複数の光電変換素子からなる受光部と、前記受光部上に被写体像を結像させる光学系と、前記受光部の出力に接続され被写体主要部の位置を表す信号を出力するネットワークと、前記受光部の出力のうち前記ネットワークの出力に基づいて選択された信号に基づいてカメラの焦点を検出する手段を具備し、前記ネットワークは前記受光部の出力に接続される複数のユニットからなる入力層と、前記入力層の個々のユニットと所定の結合の強さで結合された複数のユニットからなる単層、または複数層の中間層と、前記中間層の個々のユニットと所定の結合の強さで結合された複数のユニットからなる出力層を具備する焦点検出装置。

## 3. 発明の詳細な説明

〔産業上の利用分野〕

この発明は、どのような被写体に対してもある

程度の精度で焦点を検出できる焦点検出装置に関する。

〔従来の技術〕

従来の焦点検出装置を備えた大多数のカメラにおいては、焦点を合わすべき被写体領域がほぼ中央付近に固定されているため、写真の構図が思い通りにならない欠点があった。これを解決する手段として、特開昭54-59964号公報には、測距方向の角度を任意に変更し得るようになっていたものにおいて、測距方向の変更動作と測距方向を表示する表示部材の変位動作とを連動させる手段が開示されている。また、特開昭59-107685号公報、特開昭60-254968号公報には、輝度信号のサンプリング区画を自由に選択し得るように構成することによって、任意の被写体に焦点を合わせることが開示されている。

〔発明が解決しようとする課題〕

このような従来例では、フォーカスエリアを選択するための動作が必要であるため、操作が面倒であったり、動体などの迅速な撮影に向かない。

また、機械式の方法では、機構が複雑化したり、機構がために精度が低下するなどの欠点がある。

この発明の目的は、これらの欠点を解決するために、多数のモデルパターンによって被写体の主要部を学習させることにより、あらゆる被写体パターンに対して意図した領域に自動的に合焦させることができる焦点検出装置を提供することである。

#### 【課題を解決するための手段及び作用】

この発明による露出制御装置には、被写体パターンを入力した時に被写体主要部の位置を示す信号を出力するように学習された結合の強さで順次結合される入力層、中間層、出力層からなるネットワークが設けられる。複数の光電変換素子の出力がネットワークに入力され、ネットワークの出力により複数の光電変換素子の出力の中から被写体主要部の信号が選択され、それに基づいて焦点が検出される。

#### 【実施例】

以下、図面を参照して、この発明による焦点検

出装置の実施例を説明する。第1図にそのブロック図を示す。第1図からわかるように、この実施例は、ニューロコンピュータを使用して、露出制御、焦点検出を行なっている。そこで、先ず、第2図～第12図を参照して、ニューロコンピュータについて説明する。

第2図にニューロコンピュータのモデルを示す。このモデルはルメルハルト(Rumelhart)等によって提案されたもので、バックプロパゲーション(Back Propagation)モデル(以下、BPモデルと略す)と呼ばれる。ニューロコンピュータは多数のユニット(ニューロン)からなり、ユニットは入力層、中間層、出力層に分類されている。各ユニットは入力層→中間層→出力層の方向に接続され、ネットワーク(ニューラルネット)を形成する。各ユニットの結合の強さは学習により決定される。ただし、各層内でのユニット相互の接続はない。各ユニットのモデルを第2図に示す。

次に、このBPモデルの学習アルゴリズムの原理を説明する。あるパターンPを入力層に与えた

時、出力層に現われる実際の出力値を $O_{pj}^0$ とし、その時の望ましい出力値(以下、教師信号という)を $t_{pj}$ とすると、両者の差 $E_{pj}$ は次のように表わされる。

$$E_{pj} = 1/2 (t_{pj} - O_{pj}^0)^2 \quad \dots(1)$$

学習させるには、この誤差 $E_{pj}$ を減少させるように、全てのユニットの結合の強さを変えればよい。

パターンPを与えたときの $(K-1)$ 層の $i$ 番目のユニットから $K$ 層の $j$ 番目のユニットに対する結合の強さ $W_{ji}$ の変化量を次のように定義する。ここで、 $K$ は出力層を0として、入力層になるにつれて増える。

$$\Delta p W_{ji}^K \propto -\partial E_p / \partial W_{ji}^K \quad \dots(2)$$

$$\begin{aligned} \partial E_p / \partial W_{ji}^K &= (\partial E_p / \partial net_{pj}^K) \\ &\cdot (\partial net_{pj}^K / \partial W_{ji}^K) \quad \dots(3) \end{aligned}$$

ここで、 $net_{pj}^K = \sum_k W_{jk}^K \cdot O_{pk}^{K+1}$ である。

また、 $f$ をシグモイド(Sigmoid)関数として、

$O_{pk}^K = f(net_{pk}^K)$ と表わすと、(3)式は次のように変形される。シグモイド関数を第3図に示す。

$$\begin{aligned} \partial E_{pj} / \partial W_{ji}^K &= -\delta_{pj}^K \cdot O_{pi}^{K+1} \quad \dots(4) \end{aligned}$$

ここで、 $\delta_{pj}^K$ は第 $K$ 層における誤差の後向き伝播量であり、 $\delta_{pj}^K = -\partial E_{pj} / \partial net_{pj}^K$ である。従って、(2)式は次のように変形される。ここで、 $\eta$ は定数である。

$$\begin{aligned} \Delta p W_{ji}^K &= -\eta \cdot \delta_{pj}^K \cdot O_{pi}^{K+1} \quad \dots(5) \end{aligned}$$

出力ユニットの場合は、 $E_{pj} = 1/2 (t_{pj} - O_{pj}^0)^2$ 、 $O_{pj}^0 = f(net_{pj}^0)$ なので、出力層の後向き伝播量 $\delta_{pj}^0$ は、次のようになる。

$$\begin{aligned} \delta_{pj}^0 &= (t_{pj} - O_{pj}^0) \cdot f'(\sum_k W_{jk}^0 \cdot O_{pk}^1) \quad \dots(6) \end{aligned}$$

中間ユニットの場合は、各層内でのユニットの結合はないので、誤差の後向き伝播量は次のようになる。

$$\begin{aligned}
& \delta_{pj}^K : \\
& = -\partial E_p / \partial \text{net}_{pj}^K \\
& = \sum_k \delta_{pk}^{K-1} \\
& \quad \cdot \sum_i \{ (\partial \text{net}_{pk}^{K-1} / \partial O_{pi}^K) \\
& \quad \quad \cdot (\partial O_{pi}^K / \partial \text{net}_{pj}^K) \} \\
& = \sum_k \delta_{pk}^{K-1} (\partial \text{net}_{pk}^{K-1} / \partial O_{pj}^K) \\
& \quad \cdot f'(\text{net}_{pj}^K) \\
& = \sum_k \delta_{pk}^{K-1} W_{kj}^{K-1} \cdot f'(\text{net}_{pj}^K) \\
& = \sum_k \delta_{pk}^{K-1} W_{kj}^{K-1} \\
& \quad \cdot f'(\sum_k W_{jk}^K \cdot O_{pk}^{K+1}) \quad \dots (7)
\end{aligned}$$

(7) 式は  $\delta$  の再帰関数である。

$\Delta p W_{ji}^K$  を一般的に定式化すると、次のようになる。

$$\begin{aligned}
& \Delta p W_{ji}^K (n+1) \\
& = \eta \delta_{pj}^K \cdot O_{pi}^{K+1} + \alpha \Delta p W_{ji}^K (n) \quad \dots (8)
\end{aligned}$$

ただし、 $\Delta p W_{ji}^K (0) = 0$  であり、 $n$  は学習の回数を表わす。(8) 式の右辺の第 2 項は誤差の振動を減らし収束を速めるために加えている。(8) 式から、結合の強さは次のように更新される。

出力する。次に、結果の誤差（実際の出力と教師信号との差）を減らすように結合の強さを変える。そして、再び、学習用データを入力する。この動作を、 $\Delta W$  が収束するまで繰り返す。

第 5 図に B P モデルの基本回路構成を示す。

ランダムアクセスメモリ（以下 RAM と記す）1 は結合の強さ  $W_{ji}$  を格納し、層毎に  $k = 1 \sim N$  の  $N$  ページから成る。RAM 2 はパターン  $P$  を与えたときの結合の強さ  $W_{ji}$  の変化量  $\Delta W_{ji}$  を格納し、 $k = 1 \sim N$  の  $N$  ページから成る。RAM 3 は誤差の後向き伝播量  $\delta_{pj}$  を格納し、 $k = 0 \sim N$  の  $(N+1)$  ページから成る。RAM 4 は各ユニットの出力値  $O_{pj}$  を格納し、 $k = 0 \sim N$  の  $(N+1)$  ページから成る。5 は  $O_{pj}$  の演算回路、6 は  $\delta_{pj}$  の演算回路、7 は  $\Delta p W_{ji}$  の演算回路である。9 は全体のシーケンスを制御するシーケンスコントローラである。

第 5 図の B P モデルによる学習のプロセスを説明する。ここでは、ノイマン型のコンピュータにより B P モデルをシミュレーションした場合の動

$$\begin{aligned}
& W_{ji}^K (n+1) \\
& = W_{ji}^K (n) + \Delta p W_{ji}^K (n) \\
& \quad (K = 0, 1, 2, \dots) \quad \dots (9)
\end{aligned}$$

ここで、シグモイド関数  $f$  を

$$f = 1 / (1 + e^{-\text{net}}) \quad \dots (10)$$

で定義すると  $f' = f(1-f)$  であるので後向き伝播量は次式のように簡単化される。

出力ユニットの場合：

$$\begin{aligned}
& \delta_{pj}^0 \\
& = O_{pj}^0 (1 - O_{pj}^0) (t_{pj} - O_{pj}^0) \quad \dots (11)
\end{aligned}$$

中間ユニットの場合：

$$\begin{aligned}
& \delta_{pj}^K \\
& = O_{pj}^K (1 - O_{pj}^K) \\
& \quad \cdot \sum_i (\delta_{pi}^{K-1} \cdot W_{ki}^{K-1} (n+1)) \quad \dots (12)
\end{aligned}$$

以上からわかるように、 $\Delta W$  の計算は出力層のユニットから始めて、中間層のユニットへ移る。このように学習は入力データの処理とは逆方向に進む。

従って、B P モデルによる学習は次のように行われる。先ず、学習用のデータを入力し、結果を

作を、第 6 図～第 9 図のフローチャートを参照して説明する。第 6 図は  $O_{pj}$  演算のフローチャート、第 7 図は  $\delta_{pj}$  演算のフローチャート、第 8 図は  $W_{ji}$  演算のフローチャート、第 9 図は学習のレベル判定のフローチャートである。

ステップ 1 (S1) で RAM 1 内の結合の強さ  $W_{ji}$  をランダムな値に初期化する。ステップ 2 で入力値  $O_{pi}^{N+1}$  を RAM 4 に設定し、ステップ 3～ステップ 9 で演算回路 5 により入力層から出力層に向かって順にユニット出力値  $O_{pj}^K$  を演算していく。

次に、第 7 図のステップ 11～ステップ 20 で演算回路 6 により出力値  $O_{pj}^0$  と望ましい出力を示す教師信号  $t_{pj}$  とから (11) 式に従って出力層の誤差の後向き伝播量  $\delta_{pj}^0$  を求める。

次に、第 8 図のステップ 21～ステップ 24 で演算回路 7 により (8) 式に従って結合の強さの変化量  $\Delta p W_{ji}^0 (1)$  を求める。なお、 $\Delta p W_{ji}^0$  の初期値  $\Delta p W_{ji}^K (0)$  はすべて 0 である。ステップ 25 で演算回路 8 により (9)

式に従って結合の強さ  $W_{ji}^0$  (1) を求める。以上により、出力層の  $O_{pj}^0$ ,  $\delta_{pj}^0$ ,  $\Delta p_{W_{ji}^0}$  (1),  $W_{ji}^0$  (1) が求まる。この後、これらは初期データを更新する形で RAM 1 ~ RAM 4 に格納される。

次に、中間層の学習を行なう。第7図のフローチャートに戻り、演算回路6により以上で求めた  $\delta_{pj}^0$ ,  $W_{ji}^0$  (1)、および RAM 4 に格納されている  $O_{pj}^0$  を用いて、誤差の後向き伝播量  $\delta_{pj}^k$  を求める。次に、第8図のフローチャートにおいて、演算回路7により結合の強さの変化量  $\Delta p_{W_{ji}^k}$  (1) を(8)式に従って求め、演算回路8により結合の強さ  $W_{ji}^k$  (1) を(9)式に従って求める。出力層と同様に、以上で求めたデータは RAM 1 ~ RAM 4 に更新する形で格納されていく。以上のフローを入力層 ( $K = N + 1$ ) に向かって順次繰り返して行ない第1回目の学習が終了する。

以上の学習を複数 ( $n$ ) 回実行することにより、各ユニット間の結合の強さ  $W_{ji}$  が決定され、ある

入力パターン  $P$  を示す入力値  $O_{pj}$  を与えたときに所望の出力値  $P_{pj}$  を得るためのネットワークが自動的に形成されることになる。

第9図は、実際の出力値  $O_{pj}$  と教師信号  $t_{pj}$  との平均二乗誤差  $E_p$  を求めるフローチャートである。この値が小さくなる程、実際の出力値は望ましい出力値に近くなる。いま  $E_p$  があるしきい値  $\epsilon$  より小さければ学習を終了し、 $\epsilon$  より大きければ学習を繰り返す。

以上では、1つの入力パターン  $P$  に対する学習について述べたが、入力パターンを複数にし、それぞれのパターンに対応した複数の出力パターンを得るような学習も可能である。また、複数の入力パターンに対してある特定の1つの出力パターンを出力するように学習させることも可能である。

以上述べた BP モデルは、現在広く民生機器等で使用されているノイマン型のマイクロコンピュータで実現可能であるが、このままではニューロコンピュータの1つの大きな長所である並列処理による高速化の機能は生かされない。そのため、

第6図~第9図の処理を複数のコンピュータで並列に処理させることが好ましい。

第10図はこのための並列処理システムの構成を示す。複数のマイクロプロセッサ  $P_1 \sim P_n$  がホストプロセッサ 11 に接続される。第2図に示すニューラルネットを  $n$  個の部分ネットワークに分割し、それぞれをマイクロプロセッサ  $P_1 \sim P_n$  に割り当てる。ホストプロセッサ 11 は、マイクロプロセッサ  $P_1 \sim P_n$  相互のタイミングの制御を行ったり、マイクロプロセッサ  $P_1 \sim P_n$  に分散されているデータを統合してパターン認識などの処理を行なう。各々のマイクロプロセッサ  $P_1 \sim P_n$  は上述した演算手順に従い、第5図に示す出力値  $O_{pj}$  の連続する複数列の演算を実行する。そのため、マイクロプロセッサ  $P_1 \sim P_n$  は担当する出力値を演算するのに必要な  $\delta_{pj}$ ,  $\Delta W_{ji}$ ,  $W_{ji}$  をそれぞれ格納するための RAM と演算回路を備えている。担当する全てのユニットの出力値の演算が終了すると、各プロセッサ  $P_1 \sim P_n$  間で同期をとりながら、データの更新のた

めの通信が行なわれる。ホストプロセッサ 11 においては、学習の達成レベルの判定や、マイクロプロセッサ  $P_1 \sim P_n$  相互のタイミングの制御を行なう。

学習した結果に基づいて、パターン認識等の処理を行なう場合は、第2図に示す入力層から出力層に向かって、 $O_{pj}^k = f \left( \sum_{i=1}^n W_{ji}^k \cdot O_{pi}^{k+1} \right)$  の演算を行なっていくことにより、最終的に必要な出力値  $P_{pj}^0$  が求められる。この場合も、第11図に示すような複数のマイクロプロセッサによる分散処理を実行することによりニューラルネットの並列性による高速化がはかれる。

なお、学習の過程においては基本的に第5図に示す回路が必要になるが、学習結果を応用するだけの場合、構成は非常に簡単化される。

第11図はこの場合の基本回路構成である。入力データは入力部 12 (例えば、A/D 変換器等を指す) を介して  $O_{pj}^k = f \left( \sum_{i=1}^n W_{ji}^k \cdot O_{pi}^{k+1} \right)$  の演算を順次行なうことにより、出力データ  $O_{pj}^0$  を得る。結合の強さ  $W_{ji}^k$  の格納

される係数メモリ14はROM、または書き替え可能なROMでもよい。

第12図は学習結果を応用する製品に対する製造時の学習システムの概略ブロック図である。製品16は、結合の強さ $W_{ji}^k$ を格納するROM17を内蔵する。18は学習装置であり、ROM17と学習装置18を合せたものは基本的には第5図の装置と同一であるが、ROM17への $W_{ji}^k$ の書き込みが終了すると、製品16(ROM17)と学習装置18は分離される。なお、同一種類の各製品に対して、毎回学習させる必要はないので、ROM17をコピーして使用することも可能である。

なお、以上の説明において、BPモデルの学習とその結果の応用については、現在使われているノイマン型コンピュータによるシミュレーションにより実現してきた。これは主に学習においては、複雑なアルゴリズムが必要で、ハードウェアで自動的に各ニューロン間の接続の重みを自己組織化するのが非常に難かしいためである。しかしなが

( $-BV - AV_0$ )を演算するための回路であり、このため、絞り19の開放絞り値 $AV_0$ が入力されている。

演算回路24から出力された各光電変換素子毎のBV値はニューロコンピュータ25に供給されるとともに、選択回路(マルチプレクサ)27に供給される。ニューロコンピュータ25は被写体パターンを入力 $Opj^0$ として、 $Opj^k = f(\sum_{j \in R} W_{jk}^k \cdot Opj^{k+1})$ の演算を行ない最終的に主要部の位置 $P_{xy}$ を求める。演算に使われる結合の強さ $W_{ji}$ は、予め学習されていて、係数メモリ26に格納されている。選択回路27はこの主要部信号 $P_{xy}$ に基づいて、被写体中の主要部に対応する光電変換素子の出力BV値のみを通過させる。

選択回路27の出力は選択された主要部の輝度信号から山登りサーボ方式による焦点検出のための演算を行なう演算回路28に供給される。演算回路28の出力はドライバ29に供給され、ドライバ29はこれに基づいて、合焦機構20aを駆

ら、結合の強さ $W_{ji}$ がわかれば、学習結果を応用する機械に限定して考えると、図-1に示すBPモデルをハードウェアで構成することができる。並列処理による高速化をはかったり、廉価な民生品に应用する場合は、この方法を採用しないと、意味はない。これは、第2図の各ユニットをインバータで構成し、結合の強さ $W_{ji}$ を抵抗ネットワーク $R_{ij}$ に置き換えることで実現でき、これは、最近のLSI化の技術を使えば簡単に実現できる。

次に、第1図を参照して、以上説明したニューロコンピュータを応用した焦点検出装置を説明する。撮影カメラ20の前面には絞り19があり、絞り19を介した被写体像が光電変換素子をエリア状に配置してなる受光部21に入射される。そのため、受光部21からは、光電変換素子毎に、絞り込まれた状態における被写体の輝度情報が出力され、増幅器22、A/D変換器23を介してディジタル値化されBV値として演算回路(ALU)24に供給される。演算回路24は、絞り19を通過した光から被写体の輝度BV値

動させ、撮影レンズ20の位置を移動する。このように、この実施例は、被写体全体ではなく、主要部のみの輝度情報に基づいて、焦点検出する。30はシーケンスコントローラである。

ニューロコンピュータ25の基本ブロック構成は第5図に示す通りでもよいが、ここでは、高速化をはかるため、第10図に示すような並列コンピュータにより学習を行なう。

ここで、学習モードについて説明する。学習を効率的に進めるために、ニューラルネットワークは第14図に示すように、各行ごとに独立したニューラルネット $S_{11}, \dots$ で学習を行ない、出力層 $S_0$ で統合する。ニューラルネットワークは、入力層37、中間層38、出力層39の3層で構成されるとし、学習の原理は前述した通りである。

ここで、説明の簡単化のために、光電変換素子は、第15図に示すように、4行7列に配置されているとする。

第16図に被写体の具体例を示す。(a)はポートレートであり、この場合は、目に焦点を合わ

せるようにするため被写体主要部はP33とする。

(b)の場合は、鳥に焦点を合わせるため被写体主要部はP35とする。(c)は風景であり、この場合は塔を被写体主要部とする。ニューロコンピュータ25にこのような被写体パターンを入力し、これらの主要部の位置を教師信号として与え、実際の出力が教師信号と一致するように結合の強さ $W_{ji}$ を学習させることにより、どのような被写体が入力された場合でも自動的に正しい主要部を出力することができる。第16図には、3つの被写体しか示さないが、実際には数百のパターンについて学習を繰り返す。

なお、ニューロコンピュータ25はある程度の学習を行えば、学習時に入力されなかったパターンに対しても正しい出力を出すという優れた性質があり、被写体主要部の特定等の人間の感性によるところが大きく定式化の難しい問題解決にたいへん有効である。ニューロコンピュータの学習により、これまでノイマン型のコンピュータではプログラムできなかった膨大な種類の被写体パタ

ーンと主要部との関係が自己組織化されるので、意図通りの露出制御、焦点検出が可能となる。また、ニューロコンピュータは並列処理により高速演算が可能であるので、迅速性が要求されるカメラに適する。

この発明は上述した実施例に限定されずに、種々変形可能である。以上の説明は、被写体主要部をニューロコンピュータで学習させ、焦点検出を行なう場合について述べたが、ニューロコンピュータの教師信号として被写体の明るさ条件、あるいはパターンに応じた露出補正信号を与え、逆光補正などの学習を行なうことも可能である。

#### (発明の効果)

以上説明したようにこの発明によれば、多数のモデルパターンによって被写体の主要部を学習させることにより、あらゆる被写体パターンに対して意図した領域に自動的に合焦させることができる焦点検出装置を提供することができる。


#### 4. 図面の簡単な説明

第1図はこの発明による焦点検出装置の一実施


例のブロック図、第2図は実施例に使われるニューロコンピュータのモデルを示す図、第3図はネットワークを構成する各ユニットのモデルを示す図、第4図はシグモイド関数を示す図、第5図はニューロコンピュータのブロック図、第6図～第9図は第5図のニューロコンピュータをノイマン型コンピュータでシミュレーションした時のフローチャートであり、第6図は各ユニットの出力 $Op_j$ を求めるフローチャート、第7図は誤差の後向き伝播量 $\delta p_j$ を求めるフローチャート、第8図は結合の強さ係数 $W_{ji}$ を求めるフローチャート、第9図は学習のレベル判定のためのフローチャート、第10図は並列処理システムのブロック図、第11図は学習結果を応用する装置のブロック図、第12図は学習結果を応用する装置を学習させるシステムのブロック図、第13図は実施例の学習システムのブロック図、第14図は実施例のネットワークを示す図、第15図は実施例の光電変換素子の配置例を示す図、第16図(a)～(c)は学習させる被写体の一例を示す図である。

20a…合焦機構、21…受光部、24、28…演算回路、25…ニューロコンピュータ、26…係数メモリ、27…選択回路。


出願人代理人 井理士 坪井 淳




第 1 図



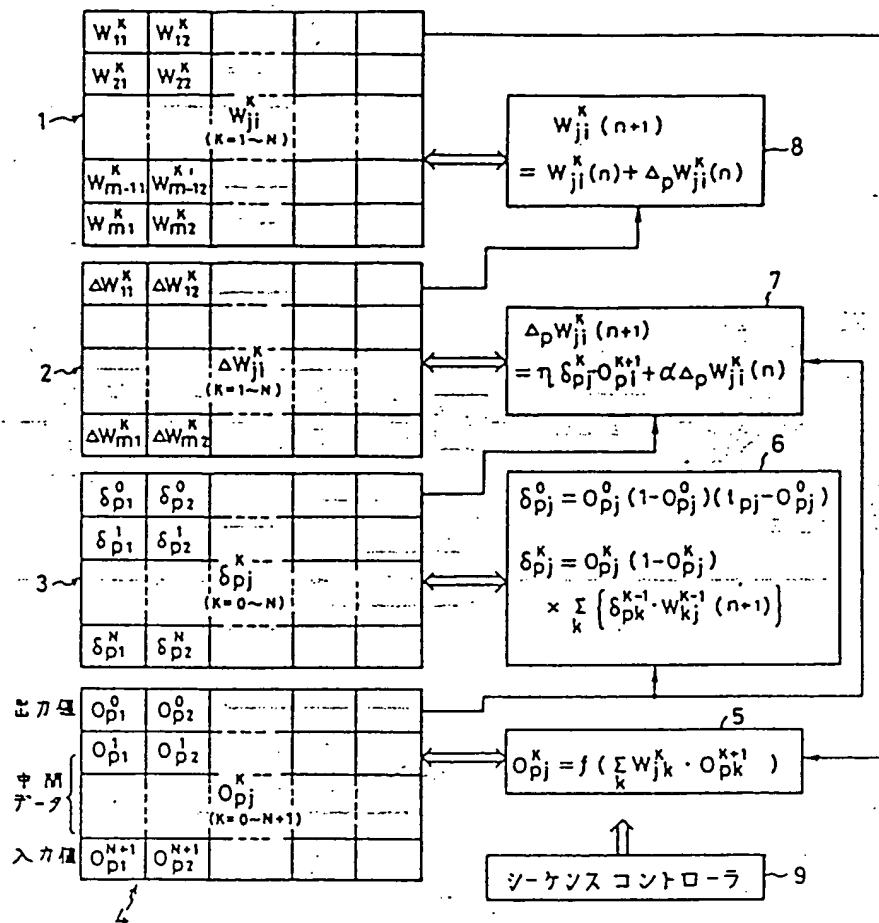
第 2 図



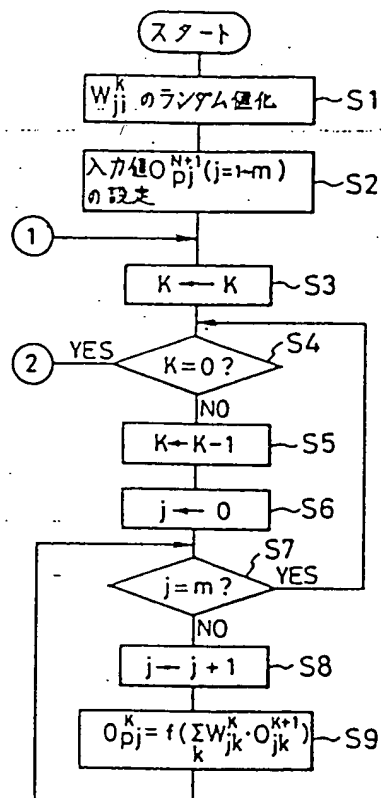
第 3 図




第 4 図



第 5 図




第 6 図




第 7 図






第 9 図


第 8 図




第 10 図




第 13 図



第 11 図



第 12 図




第 14 図

P <sub>11</sub>	P <sub>12</sub>	P <sub>13</sub>	P <sub>14</sub>	P <sub>15</sub>	P <sub>16</sub>	P <sub>17</sub>
P <sub>21</sub>	P <sub>22</sub>	P <sub>23</sub>	P <sub>24</sub>	P <sub>25</sub>	P <sub>26</sub>	P <sub>27</sub>
P <sub>31</sub>	P <sub>32</sub>	P <sub>33</sub>	P <sub>34</sub>	P <sub>35</sub>	P <sub>36</sub>	P <sub>37</sub>
P <sub>41</sub>	P <sub>42</sub>	P <sub>43</sub>	P <sub>44</sub>	P <sub>45</sub>	P <sub>46</sub>	P <sub>47</sub>


第 15 図



(a)



(b)



(c)

第 16 図

第1頁の続き

©Int. Cl.<sup>5</sup>

G 03 B 13/36

識別記号

庁内整理番号

⑦発 明 者 児 玉 晋 一

東京都渋谷区幡ヶ谷2丁目43番2号 オリンパス光学工業株式会社内

手 続 補 正 書

平成元年 6 月 5 日

特許庁長官 吉 田 文 毅 殿

7. 補正の内容

(1) 明細書第4頁、第18行目に記載の「第2図」を「第3図」と訂正する。

(2) 明細書第6頁、第2行目～第3行目に記載の「第3図」を「第4図」と訂正する。

1. 事件の表示

特願昭63-250466号

2. 発明の名称

焦 点 検 出 装 置

3. 補正をする者

事件との関係 特許出願人

(037) オリンパス光学工業株式会社

4. 代 理 人

東京都千代田区霞が関3丁目7番2号

〒100 電話 03(502)3181 (大代表)

(6881) 弁理士 坪 井 淳

5. 自 発 補 正

6. 補正の対象

明 細 書

